

تخمین سرعت موج برشی در یکی از مخازن هیدروکربوری جنوب غربی ایران با استفاده از چاه‌نمودارهای مختلف و یک روش جدید ترکیبی هوشمند

هادی فتاحی

عضو هیئت علمی دانشکده مهندسی معدن، دانشگاه صنعتی اراک

مأنده عسکری

دانشجوی کارشناسی ارشد دانشکده مهندسی معدن، دانشگاه صنعتی اراک

سعید مجددی‌فر

عضو هیئت علمی، مهندسی معدن، اکتشاف، دانشگاه صنعتی اراک

تاریخ دریافت: ۹۵/۱/۱۵ تاریخ پذیرش: ۹۵/۶/۳۰

H.fattahi@arakut.ac.ir

چکیده

تعیین سرعت موج برشی توسط روش‌هایی مانند آنالیز مغزه مستلزم صرف زمان و هزینه گزافی می‌باشد و همچنین به علت نبود مغزه‌های کافی و تغییرات سنگ‌شناسی و ناهمگنی سنگ مخزن، تعیین این پارامتر توسط روش‌های معمول از دقت چندانی برخوردار نمی‌باشد. همچنین تاکنون روابط تجربی فراوانی نیز در مورد محاسبه سرعت امواج برشی ارائه شده است، اما در بیشتر موارد استفاده از این روابط در مناطق مختلف نمی‌تواند مطلوب باشد. روش‌های هوشمند یکی از روش‌های جدید، کم هزینه و دقیقی هستند که می‌توانند با استفاده از نگاره‌های پتروفیزیکی، سرعت موج برشی مخزن را در کمترین زمان ممکن تخمین بزنند. در این مطالعه با استفاده از چاه‌نگارهای مختلف سرعت موج برشی با استفاده از یک روش ترکیبی هوشمند (ترکیب روش رگرسیون بردار پشتیبان با الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری) در یکی از مخازن هیدروکربوری جنوب غربی ایران (میدان مارون) برآورد شده است. جهت بکارگیری این روش ترکیبی هوشمند مجموعه داده‌های بدست آمده از مخزن ۳۸۰۰ بوده که به دو بخش داده‌های آموزش (۳۰۴۰ داده) و داده‌های آزمون جهت ارزیابی مدل (۷۶۰ داده) تقسیم شدند. پس از مدل‌سازی نتایج به دست آمده نشان می‌دهد که روش مذکور در برآورد غیرمستقیم سرعت موج برشی در مخازنی که این پارامتر اندازه‌گیری نشده است، دارای دقت و قابلیت بالایی است.

کلمات کلیدی: سرعت موج برشی، نگاره‌های پتروفیزیکی، مخزن هیدروکربوری، الگوریتم مبتنی بر آموزش- یادگیری

مقدمه

می‌رود (Rezaee et al., 2007a). شناخت و ارزیابی پارامترهای پتروفیزیکی و سنگ‌شناسی مخازن نفت و گاز با استفاده از نمودارهای مختلف چاه پیمایی، امروزه به‌عنوان یکی از اصلی‌ترین بخش‌های صنعت نفت در مراحل اکتشاف و تولید مخزن محسوب می‌شود. با استفاده از این روش‌ها می‌توان از نمودارهای رقومی شده چاه پیمایی به‌عنوان پارامترهای ورودی مدل استفاده نموده و ارتباطی مناسب بین داده‌های چاه پیمایی و پارامترهای پتروفیزیکی به‌دست‌آمده از مغزه برقرار کرد. در صورت عدم وجود مغزه در مخزن می‌توان با استفاده از روش‌های هوشمند پارامترهای پتروفیزیکی را برآورد نمود (Helle et al., 2001). از طرفی در سال‌های اخیر استفاده از ژئومکانیک در صنعت نفت به‌سرعت در حال گسترش است. با توجه به اهمیت سرعت موج برشی در مطالعات مخزن، این پارامتر یکی از مهم‌ترین پارامترهای اثرگذار در تعیین پارامترهای ژئومکانیکی در جهت پیش‌بینی رفتار مخازن است. در طول سال‌های اخیر، مطالعات بسیاری بر روی سرعت امواج صوتی با تمرکز بر خصوصیات پتروفیزیکی سنگ‌ها صورت گرفته است که در این مقاله به مهم‌ترین آن‌ها اشاره خواهد شد. همچنین (Sebtosheikh et al., 2015)، با استفاده از داده‌های نمودارهای چاه‌پیمایی و روش ماشین بردار پشتیبان

با توجه به استفاده‌ی روزافزون ژئومکانیک در صنعت نفت و استفاده از آن در شناسایی ساختمان زمین و تعیین خواص مکانیکی هیدروکربنی و همچنین با توجه به اهمیت بسیار بالای مطالعات پتروفیزیکی و ژئوفیزیکی مخزن و نقش آن در اکتشاف، تولید و بهره‌برداری ذخایر هیدروکربنی شناخت کامل سرعت موج برشی و فشاری سنگ‌ها از اهمیت ویژه‌ای برخوردار است. تعیین سرعت موج برشی توسط روش‌هایی چون آنالیز مغزه مستلزم صرف زمان و هزینه گزافی می‌باشد (احمدی و امیری بختیار، ۱۳۹۵). همچنین به علت نبود مغزه‌های کافی و تغییرات سنگ‌شناسی و ناهمگنی سنگ مخزن، تعیین این پارامتر توسط روش‌های معمول از دقت چندانی برخوردار نمی‌باشد. روش‌های هوشمند یکی از روش‌های جدید، کم‌هزینه و دقیقی است که می‌تواند با استفاده از نگاره‌های پتروفیزیکی سرعت موج برشی مخزن را در کمترین زمان ممکن تعیین کند. کاربردهای عمده روش‌های هوشمند در لرزه‌نگاری معکوس، تحلیل چاه نمودارها و مدل‌سازی سه بعدی مخزن است و روش‌های هوشمند به‌عنوان ابزاری برای تصمیم‌گیری در اکتشاف و توسعه مخازن نفت و گاز به کار

et al., 2011) با استفاده از روش الگوریتم ژنتیک سرعت موج برشی و فشاری را در یک مخزن کربناته واقع در میدان ابوزر و هندیجان پیش‌بینی و با مقادیر واقعی مقایسه کردند. کدخدایی و همکاران (Kadkhodaie-Ilkhchi et al., 2009) نیز مقدار تخلخل در یک مخزن ماسه سنگی را با استفاده از سایر روش‌های هوشمند پیش‌بینی نمودند. نظری و همکاران (Nazari et al., 2011) از رگرسیون برداری پشتیبان برای به دست آوردن نفوذپذیری از روی داده نگارهای چاه و اندازه‌گیری‌های مغزه استفاده نمودند. غلامی و مرادزاده (Gholami and Moradzadeh, 2012) از رگرسیون بردار پشتیبان برای پیش‌بینی نفوذپذیری استفاده کردند. آنیفوز و عبدالرحیم (Anifowose and Abdurrahim, 2011) با استفاده از روش‌های هوشمند منطق فازی و ماشین بردار پشتیبان مقدار تخلخل و نفوذپذیری را پیش‌بینی نمودند. رجیبی و همکاران (Rajabi et al., 2010) با استفاده از روش‌های هوشمند منطق فازی، الگوریتم ژنتیک و نروفازی سرعت امواج فشارشی، برشی و استوتلی از نگارهای چاه‌پیمایی مربوط به مخزن کربناتی در آبادان جنوب غربی ایران (سازند سروک) را پیش‌بینی کردند. (Al-Anazi and Gates, 2010) به پیش‌بینی تخلخل در یک مخزن ناهمگون با استفاده از رگرسیون برداری پشتیبان پرداختند و نتایج آن را با نتایج به‌دست آمده از روش‌های شبکه عصبی پرسپترون چندلایه، شبکه عصبی رگرسیون عمومی و شبکه عصبی تابع پایه‌ای شعاعی مقایسه کردند. رضایی و همکاران (Rezaee et al., 2007b) از روش‌های منطق فازی، نروفازی و شبکه‌ی عصبی مصنوعی به‌عنوان ابزارهای هوشمند برای تعیین سرعت موج برشی از داده‌های پتروفیزیکی واقع در نهشته‌های ماسه‌سنگی حوزه کارنارون استرالیا استفاده کردند یوئه و وانگ (Yue and Wang, 2007) از ماشین بردار پشتیبان برای پیش‌بینی ضخامت ماسه سنگ از روی شکل موج در یک میدان نفتی استفاده کردند. کدخدایی ایلخچی و همکاران (Kadkhodaie Ilkhchi et al., 2006) از تکنیک منطق فازی به ارزیابی نفوذپذیری و از نسبت سرعت موج فشاری به موج برشی برای تعیین نوع گروه‌های سنگی مخزن هیدروکربوری واقع در سازند کنگان سواحل جنوب غربی ایران استفاده کردند. اسکندری و همکاران (Eskandari et al., 2004) برای پیش‌بینی سرعت موج برشی در یک مخزن کربناته واقع در جنوب غربی ایران از روش شبکه عصبی مصنوعی و رگرسیون چند متغیره استفاده کردند. بوادو (Boadu, 2001) با استفاده از مدل‌های پتروفیزیکی و شبکه‌های عصبی مصنوعی و اندازه‌گیری سرعت امواج برشی و فشاری در آزمایشگاه، اشباع‌شدگی نفت در سطوح ناشناخته را پیش‌بینی کردند.

هدف از این تحقیق تخمین سرعت موج برشی در یکی از مخازن هیدروکربوری جنوب غربی ایران با استفاده از یک روش ترکیبی جدید هوشمند (ترکیب روش رگرسیون بردار پشتیبان با الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری) می‌باشد.

مروری اجمالی بر روش‌های بکار گرفته شده در این تحقیق

الف) رگرسیون بردار پشتیبان

ماشین‌های بردار پشتیبان به دو گروه عمده: الف) مدل طبقه‌بندی ماشین بردار پشتیبان و ب) مدل رگرسیون ماشین بردار پشتیبان تقسیم بندی می‌شوند. از مدل طبقه‌بندی ماشین بردار پشتیبان جهت حل مسائل طبقه بندی داده‌هایی که در کلاس‌های مختلف قرار می‌گیرند استفاده

به پیش‌بینی سنگ‌شناسی یک مخزن ناهمگن هیدروکربوری واقع در جنوب غربی ایران پرداختند. انصاری و غلامی (Ansari and Gholami, 2015) مدل رگرسیون بردار پشتیبان توسعه یافته‌ای را برای پیش‌بینی اشباع‌شدگی نفت خام در شمال آمریکا ارائه نمودند. بازاریار و همکاران (Baziar et al., 2015) از ماشین بردار پشتیبان با سه تابع کرنل مختلف (تابع پایه‌ای شعاعی، سیگموئید و خطی) و شبکه عصبی مصنوعی پرسپترون چندلایه برای ساختن مدل‌هایی جهت پیش‌بینی نفوذپذیری در یک مخزن متراکم گازی در حوضه رسوبی واشاکا استفاده کردند. احمدی و همکاران (Ahmadi et al., 2014a) با استفاده از نمودارهای پتروفیزیکی و یک مدل ترکیبی مبتنی بر دو روش هوشمند منطق فازی و ماشین بردار پشتیبان بهینه شده توسط الگوریتم ژنتیک برای پیش‌بینی تخلخل و نفوذپذیری میدان نفتی شمال خلیج فارس ارائه دادند. باقری‌پور و همکاران (Bagheripour et al., 2015) با استفاده از بردار پشتیبان رگرسیونی سرعت موج برشی سنگ مخزن نفتی واقع در سازند آسماری را پیش‌بینی نمودند. بازاریار و همکاران (Baziar et al., 2014) با استفاده از سه روش محاسباتی شامل: سیستم استنتاجی نروفازی، ماشین بردار پشتیبان و شبکه عصبی پرسپترون چندلایه مقدار نفوذپذیری در یک مخزن متراکم گازی در حوضه واشاکا آمریکا را تخمین زدند. انصاری (Ansari, 2014) با استفاده از وارون‌سازی رنگی ارتعاشات مربوط به زمین‌لغزش (Lancaster and Whitcombe, 2000) و روش ماشین کمیته‌ای مبتنی بر الگوریتم بهینه‌ساز رقابتی استعماری، میزان تخلخل یک مخزن هیدروکربوری واقع در خلیج فارس را پیش‌بینی نمودند. غلامی و مرادزاده (Gholami and Moradzadeh, 2012) از رگرسیون بردار رابط و الگوریتم ژنتیک (به‌عنوان بهینه‌ساز)، برای پیش‌بینی نفوذپذیری در یکی از مخازن کربناته جنوب ایران استفاده کردند. احمدی و همکاران (Ahmadi et al., 2014b) با استفاده از کمترین مربعات ماشین بردار پشتیبان مقدار نفوذپذیری یک مخزن هیدروکربوری را پیش‌بینی نمود. آنیفوز و همکاران (Anifowose et al., 2015) با استفاده از مدل تعمیمی ماشین بردار پشتیبان نظرات کارشناسان مختلف را باهم ترکیب و بهینه‌ترین پارامترها را جهت پیش‌بینی تخلخل و نفوذپذیری ذخایر نفتی پیشنهاد کردند. آنیفوز و همکاران (Anifowose et al., 2013) مقایسه‌ای مبتنی بر پیش‌بینی تخلخل و نفوذپذیری ذخایر نفت و گاز از میداین مختلف با ساختار زمین شناسی و سنگ شناسی متفاوت با استفاده از سه روش سیستم استنتاجی نروفازی تطبیقی و دو مدل ترکیبی (تابع عملگر ماشین بردار پشتیبان و تابع عملگر منطق فازی نوع دوم) انجام دادند. نوری طالقانی و همکاران (Nouri Taleghani et al., 2013) از روش‌های هوشمند منطق فازی، شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی لاگ‌های پتروفیزیکی در میدان نفتی جنوب غربی ایران استفاده کردند. زویداوایان‌پور و همکاران (Zoveidavianpoor et al., 2013) با استفاده از سیستم استنتاجی نروفازی تطبیقی و رگرسیون خطی چندگانه سرعت موج فشاری را از نگارهای چاه‌پیمایی در یک مخزن هیدروکربوری پیش‌بینی کردند. آسوده و باقری‌پور (Asoodeh and Bagheripour, 2012) از روش‌های هوشمند با ایجاد رابطه‌ی کمی بین نگارهای چاه‌پیمایی و سرعت امواج صوتی برای پیش‌بینی سرعت امواج فشاری، برشی و استوتلی بر روی سازند آسماری استفاده کردند. معتضدیان و همکاران (Moatazedian

پارامترها عبارتند از:

- نوع تابع کرنل

- پارامتر تابع کرنل σ

- پارامتر تنظیم کننده C

- پارامتر دقت ε مربوط به حداکثر خطا

به طور کلی قابلیت روش رگرسیون بردار پشتیبان شدیداً به آموزش

پارامترهای فوق بستگی دارد؛ مقدار پارامتر تنظیم کننده

$C \in [2^{-5}, 2^{15}]$ ، پارامتر تابع کرنل $\sigma \in [2^{-5}, 2^3]$ و پارامتر

دقت $\varepsilon \in [0.01, 0.6]$ باید در این دامنه تنظیم شوند (Fattahi, 2016).

انتخاب خوب پارامترها نقش برجسته و مهمی را در عملکرد

مطمئن رگرسیون بردار پشتیبان ایفا می‌نماید که می‌توان با استفاده از

الگوریتم‌های بهینه‌سازی، مقدار بهینه این پارامترها را به دست آورد. در

این مقاله از الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری برای پیدا

کردن مقادیر بهینه پارامترهای رگرسیون بردار پشتیبان استفاده شده

است.

ب) الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری

الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری یکی از جدیدترین

الگوریتم‌های بهینه‌سازی هوشمند است که در سال ۲۰۱۲ توسط رآو و

همکاران (Rao et al., 2012) با الهام گرفتن از فرآیند یادگیری و

آموزش، ابداع شده است. این الگوریتم یک روش بهینه‌سازی کارآمد و

مشابه سایر تکنیک‌های بهینه‌سازی تکاملی برگرفته از طبیعت و بر اساس

تأثیر یک مدرس روی یادگیری کلاس عمل می‌کند. این الگوریتم از یک

جمعیتی از جواب‌ها برای دستیابی به جواب کلی استفاده می‌نماید.

جمعیت به عنوان گروهی از یادگیران یا دانش‌آموزان یک کلاس در نظر

گرفته می‌شوند. در این الگوریتم یک مدل ریاضی برای آموزش و یادگیری

در نظر گرفته شده است، که در نهایت در دو مرحله (فاز) اجرا می‌شود و

می‌تواند منجر به بهینه‌سازی شود:

الف) مرحله یا فاز آموزش: در این مرحله، بهترین عضو جامعه، به

عنوان معلم یا مدرس انتخاب می‌شود و میانگین جمعیت را به سمت

خودش هدایت می‌کند. این فاز با یک فرآیند تصادفی مطابق معادله ۸ برای

تولید یک عضو یا موقعیت جدید در جمعیت ادامه می‌یابد.

$$X_{new,D} = X_{old,D} + r(X_{teacher,D} - T_F M_D) \quad (\text{رابطه ۸})$$

اندیس D بیانگر تعداد موضوعات یا دروس (متغیر مساله)،

$X_{old,D}$ عضو قدیمی که هنوز برای افزایش سطح دانش مجبور است از

مدرس بیاموزد و شامل یک بردار $1 \times D$ بوده که نتیجه مربوط به هر

موضوع یا درس خاص را در بر می‌گیرد، r یک عدد تصادفی در

بازه $[0, 1]$ است، $X_{teacher,D}$ بهترین عضو جمعیت در این تکرار

است که برای تغییر میانگین کلاس (جمعیت) به سمت موقعیت خودش

تلاش می‌کند، T_F فاکتور تدریس و M_D یک بردار $1 \times D$ می‌باشد

که شامل مقادیر میانگین نتایج کلاس برای هر موضوع می‌باشد. مقدار

T_F می‌تواند ۱ یا ۲ باشد که یک گام ابتکاری بوده و به صورت تصادفی با

احتمال مساوی در نظر گرفته می‌شود. عضو جدید $X_{new,D}$ در صورتی

که بهتر از عضو قدیمی باشد پذیرفته می‌شود.

ب) مرحله یا فاز یادگیری: در این مرحله، افراد جمعیت (که با هم

همکلاسی محسوب می‌شوند) با همکاری یکدیگر، دانش خود را توسعه

می‌شود و مدل رگرسیون ماشین بردار پشتیبان در حل مسائل پیش‌بینی

کاربرد دارد. همان‌گونه که بیان شد، ماشین بردار پشتیبان مبتنی بر

مینیمم کردن ریسک ساختاری می‌باشد (Vapnik and Vapnik, 1998).

همچنین برای کاربرد ماشین‌های بردار پشتیبان در مسائل

رگرسیون از تابع خطایی استفاده کرد که خطاهایی که در یک فاصله معین

به نام ε -Insensitive از مقادیر واقعی می‌باشند، را نادیده می‌گیرد

(Basak et al., 2007). این تابع به صورت رابطه (۱) تعریف می‌شود:

(رابطه ۱)

$$L(y, f(x, \alpha)) = |y - f(x, \alpha)|_{\varepsilon} = \begin{cases} 0 & \text{if } |y - f(x, \alpha)| \leq \varepsilon \\ |y - f(x, \alpha)| - \varepsilon & \text{otherwise} \end{cases}$$

این تابع خطا، مقادیر خطای کمتر از ε را در نظر نمی‌گیرد.

تابع رگرسیون به وسیله تابع زیر تخمین زده می‌شود:

$$f(x) = \langle w, x \rangle + b \quad (\text{رابطه ۲})$$

که در معادله بالا $\langle \cdot \rangle$ ضرب داخلی می‌باشد. تابع بهینه رگرسیون به وسیله

مینیمم تابع زیر بیان می‌شود.

$$\varphi(w, \xi) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N (\xi_i^+ + \xi_i^-) \quad (\text{رابطه ۳})$$

(رابطه ۴)

$$\text{Subject to } \begin{cases} y_i - (\langle w, x_i \rangle + b) \leq \varepsilon + \xi_i^+ \\ (\langle w, x_i \rangle + b) - y_i \leq \varepsilon + \xi_i^- \\ \xi_i^+, \xi_i^- \geq 0 \end{cases}$$

که C یک مقدار از پیش تعیین شده بوده و ξ_i^+, ξ_i^- متغیرهایی

هستند که قيود بالا و پایین خروجی سیستم را تعیین می‌کنند. اگر داده‌ها

به صورت خطی مجزا از هم باشند، یک سطح بهینه که داده‌ها را بدون

خطا و با حداکثر فاصله میان صفحه و نزدیکترین نقاط آموزشی (بردارهای

پشتیبان) تفکیک می‌نماید، آموزش می‌دهد. اگر نقاط آموزشی را به صورت

$[x_i, y_i]$ و بردار ورودی را به صورت $x_i \in R^n$ تعریف کنیم، در حالتی

که داده‌ها به صورت خطی قابل تفکیک باشند، معادله به صورت زیر است:

$$y = f(x) = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i \langle x_i, x \rangle + b \right] \quad (\text{رابطه ۵})$$

که در آن y خروجی معادله و y_i ارزش طبقه نمونه آزمایشی x_i می‌باشد.

بردار $x = (x_1, x_2, \dots, x_n)$ نشان‌دهنده یک داده ورودی و بردارهای

$x_i, i = 1, 2, \dots, N$ بردارهای پشتیبان هستند. اگر داده‌ها به صورت

خطی قابل تفکیک نباشند، می‌توان با اعمال پیش پردازش، نمونه‌ها را به

فضایی بالاتر برد. در این حالت رابطه ۵ به رابطه ۶ تغییر می‌یابد:

$$y = f(x) = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i \cdot k(x_i, x_j) + b \right] \quad (\text{رابطه ۶})$$

تابع $k(x_i, x_j)$ ، تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع

مختلفی از سطوح غیرخطی در فضای داده‌ها، تولید می‌کند. برای مدل

رگرسیون بردار پشتیبان از کرنل‌های مختلفی استفاده می‌شود که عبارتند

از خطی، درجه دوم، تابع پایه‌ای شعاعی و چند جمله‌ای. معمولاً، تابع

پایه‌ای شعاعی برای پیش‌بینی عملکرد بهتری دارد (Cherkassky and

Ma, 2004). معادله، تابع پایه‌ای شعاعی که در این مقاله مورد استفاده

قرار گرفته است به صورت زیر است:

$$k(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right), \quad \sigma > 0 \quad (\text{رابطه ۷})$$

در ساخت یک مدل کارآمد رگرسیون بردار پشتیبان، پارامترهای مدل

باید با استفاده از یک روش بهینه‌سازی به طور دقیق محاسبه گردند. این

پیش‌بینی سرعت موج برشی با استفاده از روش ترکیبی رگرسیون بردار پشتیبان - الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری

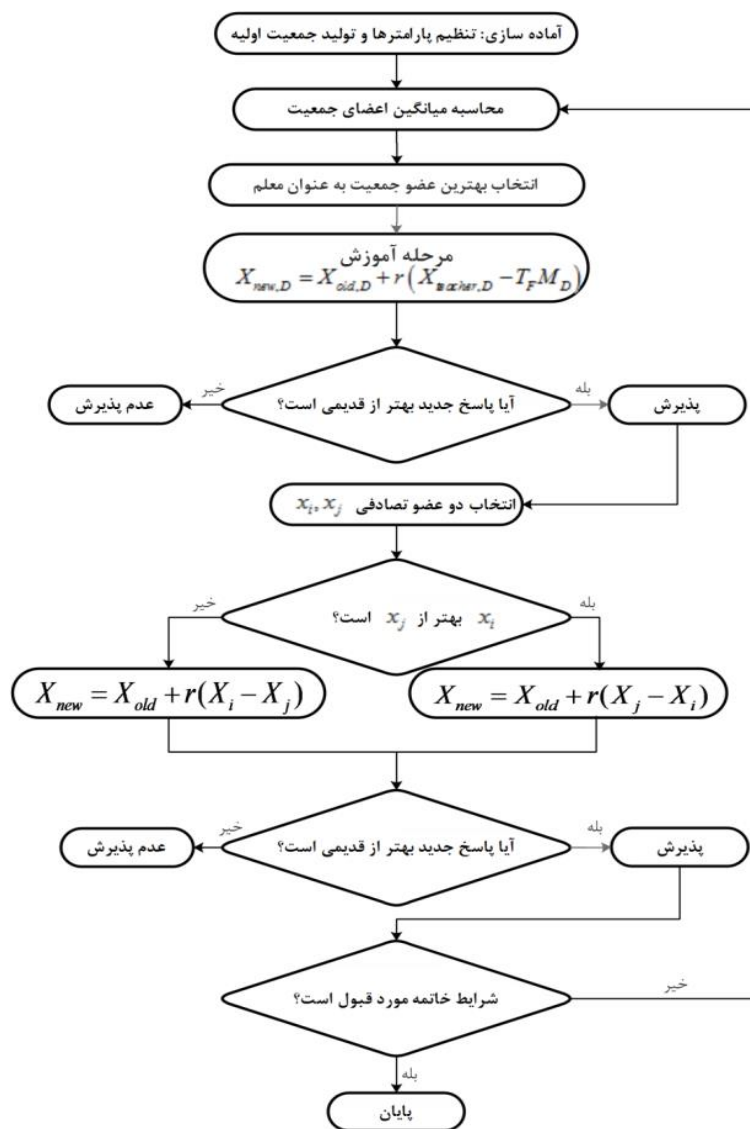
الف) ساختار داده‌ها (ورودی‌ها و خروجی) برای مدل‌سازی

در این مقاله نگارهای چاه‌پیمایی در یکی از مخازن هیدروکربوری جنوب غربی ایران (میدان مارون) بدست آمده است. میدان مارون یک تاقدیس تقریباً نامتقارن است که دارای شیب متوسط ۶۰-۴۵ درجه در یال جنوب غربی و ۲۵ الی ۴۵ درجه در یال شمال شرقی می‌باشد (رضایی و همکاران، ۱۳۹۵). همچنین دارای پیچشی در وسط ساختار است که طی آن روند میدان تقریباً ۲۰ درجه از جهت N۴۵W در شمال غرب به سمت N۶۵W در جنوب غرب تغییر می‌کند. شکل (۲) موقعیت جغرافیایی میدان نفتی مارون و میادین نفتی هم‌جوار آن را نشان می‌دهد.

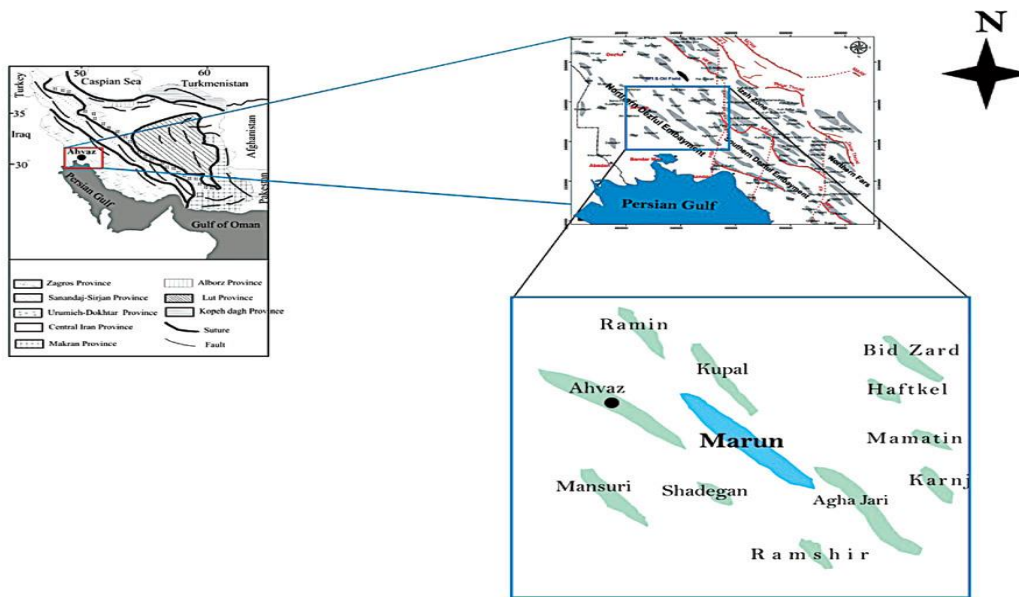
می‌دهند و رابطه ۹ روی تمامی یادگیرنده‌ها اعمال می‌شود، در این صورت، یک دانش‌آموز برخی چیزهای جدیدی را از سایر دانش‌آموزان یاد خواهد گرفت به شرط آن که سایرین دانش بالایی نسبت به او داشته باشند.

$$X_{new} = X_{old} + r(X_j - X_i) \quad (\text{رابطه ۹})$$

X_{old} عضو قدیمی است که تاکنون از تراکنش متقابل با سایر دانش‌آموزان چیزی یاد نگرفته است، r یک عدد تصادفی در بازه $[0,1]$ است و X_j, X_i دو دانش‌آموز هستند که به صورت تصادفی با شرط $j \neq i$ و شرط بهتر بودن تابع هدف X_j نسبت به X_i انتخاب شده‌اند. عضو جدید X_{new} در صورتی که بهتر از عضو قدیمی X_{old} باشد پذیرفته می‌شود. شکل (۱) فلوچارت عملکرد الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری را نشان می‌دهد.



شکل ۱. فلوچارت عملکرد الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری (Rao et al., 2012)



شکل ۲. موقعیت جغرافیایی میدان نفتی مارون و میادین نفتی هم‌جوار آن

شامل نگارهای پتروفیزیکی اشعه گاما، سرعت موج فشاری و چگالی هستند. شکل (۳) ارتباط بین ورودی‌ها و سرعت موج برشی را نشان می‌دهد. بخشی از داده‌های استفاده شده برای مدل‌سازی در جدول (۱) آورده شده است. هم‌چنین توصیف آماری داده‌های به کار رفته در این مطالعه در جدول (۲) نشان داده شده است.

در این مقاله بانک اطلاعاتی مجموعه داده‌های تصحیح شده شامل ۳۸۰۰ داده بوده که به دو بخش داده‌های آموزش (۳۰۴۰ داده) و داده‌های آزمون (۷۶۰ داده) جهت پیش‌بینی سرعت موج برشی تقسیم شدند. از بین نگارهای مختلف آنهایی که با سرعت موج برشی رگرسیونی ارتباط نزدیکی داشته‌اند به‌عنوان داده‌های ورودی در نظر گرفته شده است که

جدول ۱. بخشی از داده‌های استفاده شده برای مدل‌سازی

پارامتر خروجی	پارامترهای ورودی		
	چگالی (Kg/m^3)	سرعت موج فشاری (Km/s)	اشعه گاما
سرعت موج برشی (Km/s)	۳۱۹۱/۹۰	۲/۶۲۳۶۰	۳۵/۰۹۶۶
	۳۱۹۱/۹۰	۲/۶۱۸۵۰	۳۵/۸۴۵۶
	۳۱۹۱/۹۰	۲/۶۱۴۰۲	۳۵/۶۵۷۶
	۳۱۹۱/۹۰	۲/۶۰۳۸۴	۳۵/۹۷۰۱
	۳۱۹۱/۹۰	۲/۵۹۱۲۰	۳۶/۸۹۰۲

جدول ۲ توصیف آماری داده‌های به کار رفته در این مطالعه

پارامتر	مینیمم	ماکزیمم	میانگین	انحراف معیار
اشعه گاما	۸/۹۲	۸۵/۷۷	۲۶/۸۲	۱۶/۹۶
سرعت موج فشاری (Km/s)	۲/۱۱	۶/۸۱	۴/۳۲	۱/۰۶
چگالی (Kg/m^3)	۱۹۱۶/۷۰	۳۱۹۱/۹۰	۲۴۲۴/۷۲	۳۲۴/۵۶
سرعت موج برشی (Km/s)	۱/۶۸	۳/۶۴	۲/۶۴	۰/۳۹

همچنین در این مقاله برای ارزیابی عملکرد مدل، از دو شاخص آماری استفاده شده است که روابط مربوطه عبارتند از:

(رابطه ۱۱)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n y_i^2 - \frac{\sum_{i=1}^n y_i^2}{n}}$$

(رابطه ۱۲)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2$$

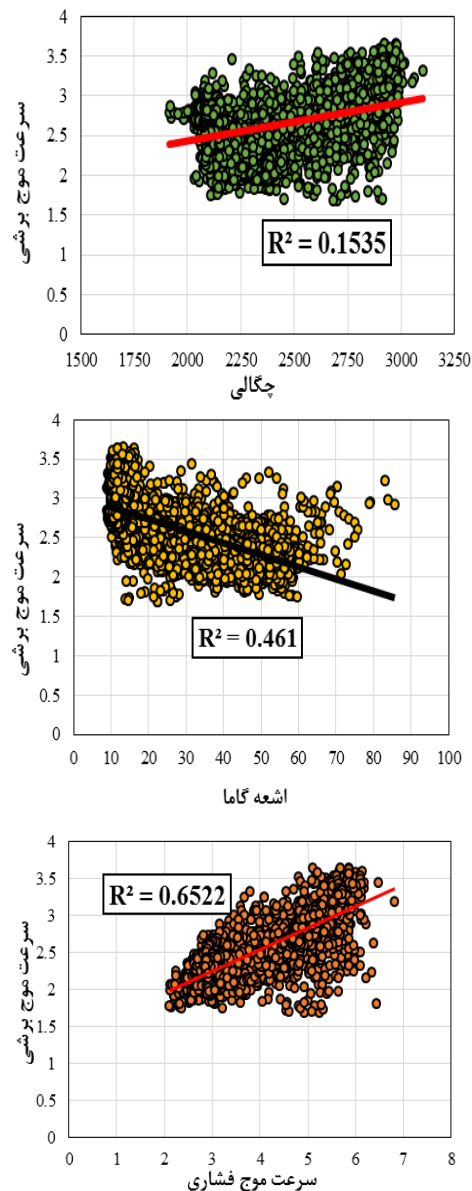
که در این روابط y_i مقدار اندازه‌گیری شده و y'_i مقدار پیش‌بینی شده می‌باشد. لازم به توضیح است که معیار ضریب همبستگی نشان دهنده انطباق بین مقادیر اندازه‌گیری شده و پیش‌بینی شده می‌باشد که بهترین حالت آن جایی است که مقدار آن یک باشد و اگر صفر باشد بدان معنی است که عملکرد مدل برای پیش‌بینی خیلی ضعیف است. معیار میانگین مربعات خطا نیز بیانگر خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده می‌باشد و هر چه مقدار آن کم‌تر باشد عملکرد مدل از اطمینان بیش‌تری برخوردار است.

ج) نتایج حاصل از مدل‌سازی

در این مدل ابتدا داده‌های ورودی و خروجی در نرم‌افزار متلب فراخوانی شدند (شکل ۴) و سپس مراحل اجرای مدل و انجام محاسبات با استفاده از رگرسیون بردار پشتیبان با تابع کرنل پایه‌ای شعاعی انجام شده است. از آنجایی که روش رگرسیون بردار پشتیبان با تابع کرنل پایه‌ای شعاعی دارای سه پارامتر مجهول و مهم (ϵ ، σ و C) در دقت مدل‌سازی می‌باشند که باید به صورت دستی و با سعی و خطای فراوان تنظیم شوند. بدیهی است که این فرآیند بسیار زمان‌بر و از دقت پایینی برخوردار می‌باشد. از طرفی همان‌طور که ذکر شد مقدار خطای مدل‌سازی به کم یا زیاد شدن این پارامترها بسیار حساس می‌باشد بطوریکه کوچکترین تغییر باعث بالا و پایین رفتن خطا می‌شود. بنابراین برای بهینه‌سازی پارامترهای مدل بهتر است که از یک الگوریتم بهینه‌ساز کمک گرفته شود که در این مقاله برای بدست آوردن مقادیر ϵ ، σ و C از الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری بهره گرفته شده است. در (شکل ۵) فلوجارت رگرسیون بردار پشتیبان بهینه‌یافته توسط الگوریتم مبتنی بر آموزش و یادگیری نشان داده شده است. مقادیر بهینه‌یافته مقادیر ϵ ، σ و C که توسط الگوریتم بهینه‌ساز پیشنهاد شده در (جدول ۳) نشان داده شده است. همچنین مقادیر پارامترهای استفاده شده برای الگوریتم بهینه‌سازی مبتنی بر الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری در جدول (۴) آورده شده است.



شکل ۴. ساختار روش هوشمند ترکیبی استفاده شده در این پژوهش



شکل ۳. نمودار ارتباط بین نگارهای چگالی، اشعه گاما و سرعت موج فشاری با سرعت موج برشی

ب) پیش پردازش داده‌ها و شاخص‌های آماری جهت ارزیابی

عملکرد مدل

برای مدل‌سازی و ورودی داده‌ها، اکثراً لازم است که دامنه تغییرات داده‌ها مشابه یکدیگر باشند که در اصطلاح این عمل را، نرمال‌سازی داده‌ها می‌نامند. نرمال‌سازی داده‌ها در این مطالعه توسط رابطه زیر انجام گرفته است که این رابطه دامنه داده‌ها را در بازه [۰ ۱] قرار می‌دهد.

$$p_n = \frac{p - p_{\min}}{p_{\max} - p_{\min}} \quad (\text{رابطه ۱۰})$$

که در آن: p_n داده نرمال شده، p داده حقیقی، p_{\min} کمینه داده حقیقی و p_{\max} بیشینه داده حقیقی هستند.


جدول ۳. مقادیر بهینه پارامترهای رگرسیون بردار پشتیبان توسط الگوریتم بهینه سازی مبتنی بر آموزش و یادگیری

پارامتر	بازه تعریف شده	مقدار بهینه شده
C	[۰/۰۳ ۳۰۰۰]	۲۷۴۰/۰۱۳
σ	[۰/۰۳ ۴]	۲/۵۸۰۴۶۶۲۰۷
ϵ	[۰/۰۱ ۰/۶]	۰/۰۶۵۵۴۸۸

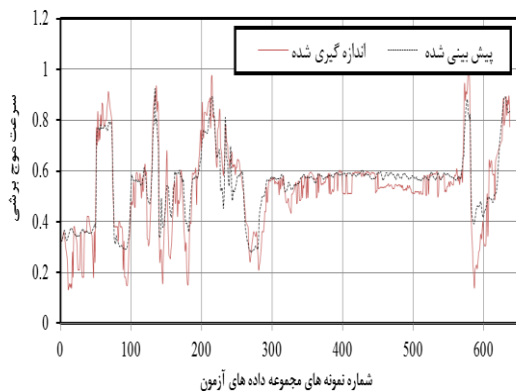
جدول ۴. مقادیر پارامترهای الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری در حالت بهینه

پارامترها	تعریف	مقدار
MAX IT	ماکزیمم مقدار حلقه تکرار الگوریتم	۱۰۰
N POP	اندازه جمعیت	۲۰

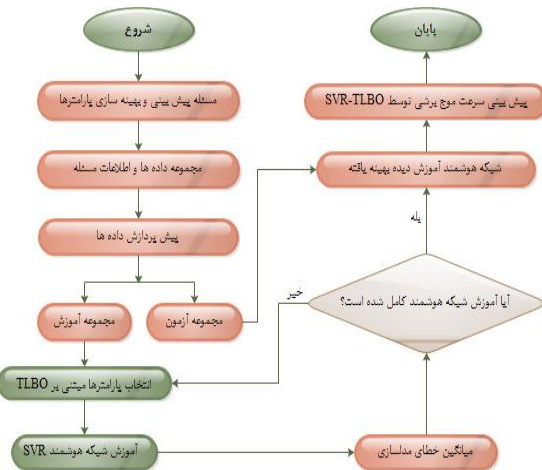
قرار گرفت. (شکل‌های ۶ و ۷) همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده در مجموعه داده‌های آموزش و آزمون را نشان می‌دهند.



شکل ۷. نمودار ضریب همبستگی بین سرعت موج برشی اندازه‌گیری شده و پیش بینی شده در مرحله آزمایش

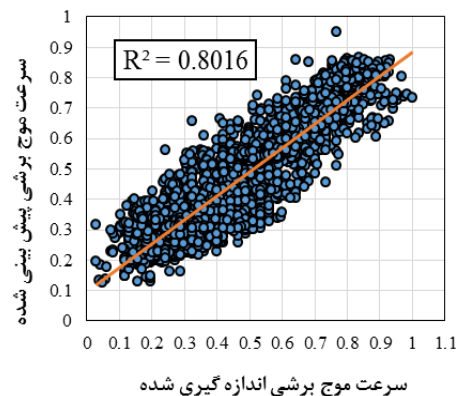


(ب)




شکل ۵. فلوچارت رگرسیون بردار پشتیبان یافته توسط الگوریتم مبتنی بر آموزش و یادگیری

برای یافتن کاراترین مدل، تمامی مدل‌ها با داده‌های چاه آزمون (چاهی که اطلاعات آن فقط به منظور آزمون مدل است) مورد بررسی



شکل ۶. نمودار ضریب همبستگی بین سرعت موج برشی اندازه‌گیری شده و پیش‌بینی شده در مرحله آموزش



(الف)

شکل ۸. نمودار سرعت موج برشی پیش‌بینی شده و سرعت موج برشی اندازه‌گیری شده (الف): در مرحله آموزش، (ب): در مرحله آزمون

روی نمودارهای چاه‌نگاری به تخمین سرعت موج برشی پردازند بسیار مفید خواهد بود. یک روش جایگزین برای مدل کردن روابط پارامتری بین سرعت موج برشی و ویژگی‌های مخزن هیدروکربوری، استفاده از روش‌های هوشمند می‌باشد. در این پژوهش از یک روش هوشمند ترکیبی جدید به نام ترکیب روش رگرسیون بردار پشتیبان با الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری برای پیش بینی سرعت موج برشی در یکی از مخازن هیدروکربوری جنوب غربی ایران (میدان مارون) استفاده شده است. نتایج حاصل شده در این تحقیق نشان داد که روش جدید و ترکیبی پیشنهاد شده از دقت و قابلیت بالایی در پیش بینی سرعت موج برشی مخزن هیدروکربوری دارد. در این مدل‌سازی، الگوریتم مبتنی بر آموزش و یادگیری توانست مقدار بهینه و دقیق سه پارامتر مجهول σ ، ϵ و C در روش رگرسیون بردار پشتیبان را برآورد کند. پیدا کردن بهینه‌ترین مقادیر پارامترهای مجهول به صورت دستی فرآیندی بسیار زمان‌بر و دارای خطای فراوان می‌باشد و همچنین قابلیت رگرسیون بردار پشتیبان شدیداً به مقدار پارامترهای فوق بستگی دارد. الگوریتم بهینه‌ساز معرفی شده در این مقاله می‌تواند در کمترین زمان ممکن و با بالاترین دقت بهینه‌ترین مقدار را بیابد. کم بودن تعداد پارامترها نیز از ویژگی‌های بارز الگوریتم مبتنی بر آموزش و یادگیری نسبت به سایر الگوریتم‌های بهینه‌ساز است. در ضمن این روش می‌تواند ابزاری مؤثر برای تخمین سایر خواص پتروفیزیکی سنگ مخزن نیز باشد.

بعلاوه مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده سرعت موج برشی توسط مدل ترکیبی روش ترکیبی رگرسیون بردار پشتیبان-الگوریتم بهینه‌ساز مبتنی بر آموزش و یادگیری در مراحل آموزش و آموزش در (شکل ۸) نشان داده شده است. همچنین در این مدل‌سازی مقدار میانگین مربعات خطا (MSE) در مرحله آموزش ۰/۰۱۰۷ و در مرحله آزمون ۰/۰۰۸۷ به دست آمد. نتایج حاکی از آن است که این مدل قابلیت بالایی در برآورد سرعت موج برشی با استفاده از مجموعه پارامترهای ورودی ذکر شده را دارد و می‌تواند برای پروژه‌های دیگر با شرایط مشابه، به‌طور مطلوبی مورد استفاده قرار گیرد.

نتیجه‌گیری

سرعت موج برشی یکی از مهم‌ترین پارامترها در بررسی‌های اکتشافی صنعت نفت و گاز محسوب می‌شود که از پارامترهای مختلف سنگ (مثل سرعت موج فشاری، سیال منفذی و غیره) تأثیر می‌پذیرد و می‌تواند بیانگر خصوصیات فیزیکی سنگ نیز باشد. از این رو، سرعت موج برشی می‌تواند در تعیین نوع لیتولوژی سازند، سیال منفذی و تعیین پارامترهای ژئومکانیکی سازند نظیر مدول برشی، مدول حجمی و غیره به کار رود. اما متأسفانه داده‌های مربوط به سرعت امواج برشی در تمامی چاه‌ها به‌ویژه چاه‌های قدیمی وجود ندارد. این مساله تنها به خاطر گران بودن مغزه‌گیری و انجام اندازه‌گیری‌های آزمایشگاهی نیست؛ بلکه در برخی چاه‌ها مانند چاه‌های افقی مغزه‌گیری عملاً غیر ممکن است ولی تقریباً از تمامی چاه‌ها نمودار گیری صورت می‌گیرد. بنابراین استفاده از روشی که بتواند از

منابع

- احمدی، ر.، امیری بختیار، م. ص.، ۱۳۹۵، ارزیابی خواص پتروفیزیکی سازند آسماری میدان نفتی بزرگ مارون واقع در جنوب غرب کشور با استفاده از نگارهای چاه پیمایی، مجله زمین‌شناسی کاربردی پیشرفته، شماره ۱۹، ص ۲۲-۱۰.
- رضایی، ر.، زارعی محمودآبادی، ه.، کلانتری، ن.، علی یاری، ز.، ۱۳۹۵، بررسی کیفیت آب مخزن سد مارون با استفاده از روش تحلیل آماری چند متغیره بر پایه همبستگی و تغییرات داده‌های کیفی آب، بهبهان، خوزستان، مجله زمین‌شناسی کاربردی پیشرفته، شماره ۱۹، ص ۸۵-۸۲.
- Ahmadi M.-A., Ahmadi M.R., Hosseini S.M., Ebadi M., 2014a, Connectionist model predicts the porosity and permeability of petroleum reservoirs by means of petro-physical logs: Application of artificial intelligence. Journal of Petroleum Science and Engineering, Vol: 123, P: 183-200.
- Ahmadi M.A., Ebadi M., Marghmaleki P.S., Fouladi M.M., 2014b, Evolving predictive model to determine condensate-to-gas ratio in retrograded condensate gas reservoirs. Fuel, Vol: 124, P: 241-257.
- Al-Anazi A., Gates I., 2010, Support vector regression for porosity prediction in a heterogeneous reservoir: A comparative study. Computers & Geosciences, Vol: 36, No:12, P: 1494-1503.
- Anifowose F., Abdurraheem A., 2011, Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization. Journal of Natural Gas Science and Engineering, Vol: 3, No:3, P: 505-517.
- Anifowose F., Labadin J., Abdurraheem A., 2015, Improving the prediction of petroleum reservoir characterization with a stacked generalization ensemble model of support vector machines. Applied Soft Computing, Vol: 26, P: 483-496.
- Anifowose F.A., Labadin J., Abdurraheem A., 2013, Prediction of petroleum reservoir properties using different versions of adaptive neuro-fuzzy inference system hybrid models. Int. J. Comput. Inf. Syst. Ind. Manage. Appl, Vol: 5, P: 413-426.
- Ansari H.R., 2014, Use seismic colored inversion and power law committee machine based on imperial competitive algorithm for improving porosity prediction in a heterogeneous reservoir. Journal of Applied Geophysics, Vol: 108, P: 61-68.
- Ansari H.R., Gholami A., 2015, An improved support vector regression model for estimation of saturation pressure of crude oils. Fluid Phase Equilibria, Vol: 402, P:124-132.
- Asoodeh M., Bagheripour P., 2012, Prediction of compressional, shear, and stoneley wave velocities from conventional well log data using a committee machine with intelligent systems. Rock mechanics and rock engineering, Vol: 45, No:1, P: 45-63.
- Bagheripour P., Gholami A., Asoodeh M., Vaezzadeh-Asadi M., 2015, Support vector regression based determination

- of shear wave velocity. *Journal of Petroleum Science and Engineering*, Vol: 125, P: 95-99.
- Basak D., Pal S., Patranabis D.C., 2007, Support vector regression. *Neural Information Processing-Letters and Reviews*, Vol: 11, No:10, P: 203-224.
- Baziar S., Gafoori M.M., Pour M., Mehdi S., Bidhendi M.N., Hajiani R., 2015, Toward a Thorough Approach to Predicting Klinkenberg Permeability in a Tight Gas Reservoir: A Comparative Study. *Iranian Journal of Oil & Gas Science and Technology*, Vol: 4, No:3, P: 18-36.
- Baziar S., Tadayoni M., Nabi-Bidhendi M., Khalili M., 2014, Prediction of permeability in a tight gas reservoir by using three soft computing approaches: A comparative study. *Journal of Natural Gas Science and Engineering*, Vol: 21, P: 718-724.
- Boadu F.K., 2001, Predicting oil saturation from velocities using petrophysical models and artificial neural networks. *Journal of Petroleum Science and Engineering*, Vol: 30, No:3, P: 143-154.
- Cherkassky V., Ma Y., 2004, Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, Vol: 17, No:1, P: 113-126.
- Eskandari H., Rezaee M., Mohammadnia M., 2004, Application of multiple regression and artificial neural network techniques to predict shear wave velocity from wireline log data for a carbonate reservoir South-West Iran. *CSEG recorder*, Vol: 42, P: 48.
- Fattahi H., 2016, Application of improved support vector regression model for prediction of deformation modulus of a rock mass. *Engineering with Computers*, P: 1-14.
- Gholami R., Moradzadeh A., 2012, Support vector regression for prediction of gas reservoirs permeability. *Journal of Mining and Environment*, Vol: 2, No:1, P: 1-14.
- Helle H.B., Bhatt A., Ursin B., 2001, Porosity and permeability prediction from wireline logs using artificial neural networks: a North Sea case study. *Geophysical Prospecting*, Vol: 49, No:4, P: 431-444.
- Kadkhodaie-Ilkhchi A., Rezaee M.R., Rahimpour-Bonab H., Chehrazi A., 2009, Petrophysical data prediction from seismic attributes using committee fuzzy inference system. *Computers & Geosciences*, Vol: 35, No:12, P: 2314-2330.
- Kadkhodaie Ilkhchi A., Rezaee M., Moallemi S.A., 2006, A fuzzy logic approach for estimation of permeability and rock type from conventional well log data: an example from the Kangan reservoir in the Iran Offshore Gas Field. *Journal of Geophysics and Engineering*, Vol: 3, P: 356-369.
- Lancaster S., Whitcombe D. (2000). Fast track coloured inversion, SEG.
- Moatazadian I., Rahimpour-Bonab H., Kadkhodaie-Ilkhchi A., Rajoli M., 2011, Prediction of shear and Compressional Wave Velocities from petrophysical data utilizing genetic algorithms technique: A case study in Hendijan and Abuzar fields located in Persian Gulf. *Geopersia*, Vol: 1, No:1, P: 1-17.
- Nazari S., Kuzma H.A., Rector Iii J.W. (2011). Predicting permeability from well log data and core measurements using support vector machines. 2011 SEG Annual Meeting, Society of Exploration Geophysicists.
- Nouri Taleghani M., Saffarzadeh S., Karimi Khaledi M., Zargar G., 2013, Development of an Intelligent System to Synthesize Petrophysical Well Logs. *Iranian Journal of Oil & Gas Science and Technology*, Vol: 2, No:3, P: 11-24.
- Rajabi M., Bohloli B., Ahangar E.G., 2010, Intelligent approaches for prediction of compressional, shear and Stoneley wave velocities from conventional well log data: A case study from the Sarvak carbonate reservoir in the Abadan Plain (Southwestern Iran). *Computers & Geosciences*, Vol: 36, No:5, P: 647-664.
- Rao R.V., Savsani V.J., Vakharia D., 2012, Teaching-learning-based optimization: an optimization method for continuous non-linear large scale problems. *Information Sciences*, Vol: 183, No:1, P: 1-10.
- Rezaee M.R., Ilkhchi A.K., Barabadi A., 2007a, Prediction of shear wave velocity from petrophysical data utilizing intelligent systems: An example from a sandstone reservoir of Carnarvon Basin, Australia. *Journal of Petroleum Science and Engineering*, Vol: 55, No:3, P: 201-212.
- Rezaee M.R., Kadkhodaie-Ilkhchi A., Alizadeh P.M., 2007b, Intelligent approaches for the synthesis of petrophysical logs. *Journal of Geophysics and Engineering*, Vol: 5, No:1, P: 12.
- Sebtosheikh M.A., Motafakkerfard R., Riahi M.-A., Moradi S., Sabety N., 2015, Support vector machine method, a new technique for lithology prediction in an Iranian heterogeneous carbonate reservoir using petrophysical well logs. *Carbonates and Evaporites*, Vol: 30, No:1, P: 59-68.
- Vapnik V.N., Vapnik V. (1998). *Statistical learning theory*, Wiley New York.
- Yue Y., Wang J., 2007, SVM method for predicting the thickness of sandstone. *Applied Geophysics*, Vol: 4, No:4, P: 276-281.
- Zoveidavianpoor M., Samsuri A., Shadizadeh S.R., 2013, Adaptive neuro fuzzy inference system for compressional wave velocity prediction in a carbonate reservoir. *Journal of Applied Geophysics*, Vol: 89, P: 96-107.